

Londrina, PR / Outubro, 2025

Modelo matemático indicando a influência do déficit de pressão de vapor (DPV) na estimativa da produtividade da soja

Sergio Luiz Gonçalves⁽¹⁾, José Renato Bouças Farias⁽²⁾, Luís Guilherme Teixeira Crusiol⁽³⁾, Rubson Natal Ribeiro Sibalde⁽⁴⁾, Giovani Veronezzi⁽⁵⁾

⁽¹⁾ Engenheiro-agrônomo, doutor em Agronomia, pesquisador da Embrapa Soja, Londrina, PR. ⁽²⁾

Engenheiro-agrônomo, doutor em Fitotecnia, pesquisador da Embrapa Soja, Londrina, PR. ⁽³⁾ Geógrafo, doutor em Agronomia, pesquisador visitante, bolsista FAPED/Embrapa Soja, Londrina, PR. ⁽⁴⁾ Matemático, especialista em Estatística, Londrina, PR. ⁽⁵⁾ Biólogo, especialista em Bioquímica Aplicada, Londrina, PR.

Resumo - O déficit de pressão de vapor (DPV) é uma variável agrometeorológica que integra dados de temperatura e umidade relativa do ar. É importante para indicar o poder que a atmosfera possui de retirar água da superfície terrestre, sendo fundamental para a compreensão dos fatores que influenciam o desenvolvimento das plantas em condições climáticas adversas. Quando ele é alto o ar fica mais seco, ocorrendo maior perda de água da superfície terrestre por transpiração das plantas e por evaporação de água da superfície. Nessas condições, as plantas podem sofrer por deficiência hídrica. Neste trabalho, foram correlacionados dados de produtividade média de soja de 104 municípios dos estados do Rio Grande do Sul, Santa Catarina, Paraná e Mato Grosso do Sul com o DPV calculado para o período crítico do florescimento e enchimento de grãos da cultura. Foram utilizados dados de produtividade média municipal de soja (em kg/ha) e respectivos dados de clima, de 306 safras, entre os anos de 2019/2020 e de 2024/2425, num estudo de regressão linear múltipla, com a obtenção de um modelo matemático que leva em conta a influência do DPV na estimativa da produtividade da cultura. A equação obtida mostrou ser bastante expressiva e significativa uma vez que, apesar de representar uma vasta região de produção (aproximadamente 18 milhões de hectares) e mesmo sem considerar a imensa diversidade de ambientes de produção, mostrou um erro médio de estimativas de apenas 14,1% em relação às produtividades observadas, sendo útil em trabalhos de previsão e acompanhamento de safras.

Termos para indexação: *Glycine max*, soja, temperatura, umidade relativa do ar.

Mathematical model indicating the influence of the vapor pressure deficit (VPD) on the estimation of soybean productivity

Abstract - Vapor pressure deficit (VPD) is an agrometeorological variable that integrates temperature and relative humidity data. It is important to indicate the power that the atmosphere must remove water from the Earth's

Embrapa Soja

Rod. Carlos João Strass, s/n,
acesso Orlando Amaral
Caixa Postal 4006,
CEP 86085-981
Distrito de Warta
Londrina, PR
(43) 3371 6000
www.embrapa.br/soja
www.embrapa.br/fale-conosco/sac

Comitê Local de Publicações

Presidente

Roberta Aparecida Carnevali

Secretária-executiva

Regina Maria Villas Bôas de
Campos Leite

Membros

Adônis Moreira, Clara Beatriz
Hoffmann-Campo, Claudine Dinali
Santos Seixas, Claudio Guilherme
Portela de Carvalho, Fernando
Augusto Henning, Leandro
Eugênio Cardamone Diniz, Liliane
Márcia Mertz-Henning, Maria
Cristina Neves de Oliveira

Edição executiva

Vanessa Fuzinatto Dall'Agnol

Revisão de texto

Regina Maria Villas Bôas de
Campos Leite

Normalização

Valéria de Fátima Cardoso
(CRB- 9/1188)

Projeto gráfico

Leandro Sousa Fazio

Diagramação

Vanessa Fuzinatto Dall'Agnol

Publicação digital: PDF

Todos os direitos
reservados à Embrapa.

surface, being fundamental for understanding the factors that influence the development of plants in adverse climatic conditions. When it is high, the air becomes drier, resulting in greater loss of water from the Earth's surface through plant transpiration and evaporation of water from the surface. Under these conditions, plants may suffer from water deficiency. In this work, average soybean productivity data from 104 municipalities in the states of Rio Grande do Sul, Santa Catarina, Paraná and Mato Grosso do Sul, Brazil, were correlated with the VPD calculated for the critical period of flowering and grain filling of the crop. Municipal average soybean productivity data (in kg/ha) and respective climate data were used, from 306 harvests, between the years of 2019/2020 and 2024/2025, in a multiple linear regression study, obtaining a mathematical model that considers the influence of VPD in estimating crop productivity. The equation obtained proved to be quite expressive and significant since, despite representing a vast production region (approximately 18 million hectares) and even without considering the immense diversity of production environments, it showed an average estimation error of only 14.1% in relation to observed productivity, making it useful in harvest forecasting and monitoring work.

Index terms: *Glycine max*, soybean, temperature, relative humidity.

Introdução

A cultura da soja foi introduzida no Brasil no final do século XIX. Despertou grande interesse apenas a partir da década de 1960, quando passou a ser impulsionada pela ciência agrônômica e pelos agricultores, inicialmente no Sul do Brasil, o que culminou no desenvolvimento de cultivares adaptadas ao clima tropical. A partir da década de 1970, quando ela deixou de ser restrita ao Sul do Brasil (especialmente ao Rio Grande do Sul), passou a expandir-se para outras regiões. A introdução de variedades

adaptadas ao Cerrado permitiu a expansão rumo ao Centro-Oeste. A partir dos anos 2000, a soja consolidou-se como a principal cultura agrícola do Brasil, posicionando o país como o maior produtor e exportador mundial. A expansão continuou em direção ao Norte e Nordeste, com destaque para Maranhão, Tocantins, Piauí e Bahia (MaToPiBa). Hoje, a soja é um dos pilares da agricultura brasileira, representando uma importante fonte de divisas para o país. Na safra 2024/2025 (Conab, 2025), os seis principais estados produtores foram Mato Grosso (com uma área cultivada de 12,7 milhões de hectares), Paraná (com 5,9 milhões), Rio Grande do Sul (com 6,9 milhões), Goiás (com 4,9 milhões), Mato Grosso do Sul (com 4,3 milhões) e Bahia (com 2,1 milhão de hectares cultivados). Atualmente, ainda segundo a Conab, em seu 7º Levantamento da Safra de Grãos 2024/2025 (Conab, 2025), a área cultivada com soja no Brasil foi estimada em 47,61 milhões de hectares, com uma projeção de produção de 168,34 milhões de toneladas de grãos. Pode-se dizer, resumidamente, que a região Centro-Oeste cultiva cerca de 46% da soja brasileira, a região Sul cerca de 28% e as demais regiões contribuem com aproximadamente 25% da área cultivada.

Diante de muitos avanços tecnológicos ocorridos ao longo das últimas décadas, houve um crescimento significativo na produtividade da cultura. Esse avanço geográfico e tecnológico foi viabilizado, além de variedades adaptadas às diversas regiões, pela correção dos solos, o uso do sistema plantio direto e rotação de culturas, o uso eficiente de fertilizantes, o controle de pragas e doenças, o uso de mecanização entre outros avanços. Entre as safras de 1996/1997 e 2020/2021, a produtividade média nacional da soja aumentou aproximadamente 1.200 kg/ha, representando um crescimento de cerca de 60%. Isso explica a evolução da produtividade de 2.000 kg/ha na safra 1996/1997 para 3.536 kg/ha na safra 2024/2025 (Figura 1).




Figura 1. Evolução da produtividade da cultura da soja de meados da década de 1990 até a safra 2024/2025, nos estados do Paraná, Rio Grande do Sul, Mato Grosso do Sul, Santa Catarina e no Brasil.

Fonte: Conab (2025).

Nesse cenário, entre os diversos incrementos tecnológicos, ocorreu o desenvolvimento e aperfeiçoamento de várias técnicas usadas para estimar a produção e a produtividade das safras agrícolas. Essas podem variar conforme o nível tecnológico disponível, as informações disponíveis, o tipo de cultura e a escala da estimativa (municipal, estadual ou nacional). Podem ser feitas desde os tradicionais levantamentos de campo, baseados em entrevistas com produtores, visitas a propriedades e observações visuais (técnicas muito utilizadas por órgãos governamentais), por amostragens de talhões, questionários estruturados, observação fenológica das culturas, entre outras e até por sensoriamento remoto, com o uso de imagens orbitais de satélites. No caso das imagens de satélite, isso permite o monitoramento de grandes áreas, com o objetivo de detecção de área semeada, ciclo de culturas e anomalias de vegetação, com o uso de índices de vegetação e modelos espectrorradiométricos, entre outros procedimentos. Existe também a modelagem agrometeorológica, que integra dados de clima, como temperatura, precipitação pluviométrica, radiação solar, entre outros, juntamente com outras variáveis, para simular a produtividade de culturas. Essas informações são muito úteis e permitem um elevado grau de acurácia quando se tem uma série confiável e consistente de dados.

Esse último aspecto abordado é muito importante porque é sabido que grande parte da variabilidade dos fatores de produção agrícola ocorre devido aos elementos climáticos. Estima-se que perto da metade das variações de produtividade das lavouras são explicadas pelas incertezas do clima (Sentelhas et al., 2015). A deficiência hídrica é o elemento mais importante para as quedas de produtividade. Os períodos secos alteram a disponibilidade hídrica e a evapotranspiração do sistema agrícola originando um balanço hídrico desfavorável, que pode prejudicar sensivelmente as plantas, principalmente em momentos críticos como o florescimento e o desenvolvimento de grãos. Nessas condições de deficiência hídrica, outro elemento fundamental é o déficit de pressão de vapor (DPV), que mostra o quanto o ar está seco, indicando a demanda hídrica da atmosfera. Ele pode ser obtido pela combinação entre dados de temperatura e umidade relativa do ar (UR). Esta apresenta valores mais elevados em baixas temperaturas e mais baixos quando ocorrem altas temperaturas, para uma mesma quantidade de vapor d'água na atmosfera. Em resumo, a UR dá a porcentagem de vapor d'água presente no ar em relação ao máximo possível a uma dada temperatura.

Esses elementos climáticos são fundamentais para demonstrar o quanto o clima pode interferir na produtividade agrícola. A relação entre DPV

e evapotranspiração mostra que, quando o DPV é alto, indicando grande demanda evaporativa pela atmosfera, a taxa de evapotranspiração também é alta. Quando o DPV está baixo, o ar já está saturado com umidade, tornando mais difícil para a planta perder água para o ambiente. Outros fatores climáticos, como temperatura, velocidade do vento e radiação solar, também influenciam a evapotranspiração, mas o DPV é um indicador direto da disponibilidade de água para a atmosfera. Um ar seco (alto DPV) pode ser um sinal de que o solo está perdendo água rapidamente, o que pode aumentar o estresse hídrico para as plantas. A relação entre DPV e a produtividade da soja pode variar conforme o estágio de desenvolvimento da planta. Durante o florescimento (estádios R1 e R2), o DPV deve ser moderado, uma vez que se ele for muito alto a soja pode ter sua taxa de transpiração aumentada demasiadamente, consumindo rapidamente a água do solo, o que pode resultar em estresses, com aborto de flores e queda de produtividade. Nos estádios de enchimento de grãos (R5 a R6), o DPV alto pode ser prejudicial devido à maior demanda por água pela planta para garantir a qualidade e o peso normal dos grãos. Em condições extremas, a falta de umidade no solo, associada a um DPV elevado, pode comprometer o rendimento. Assim, além dos métodos de previsão de safras acima descritos é possível, partindo-se de conhecimentos de variáveis do clima, elaborar equações matemáticas que possibilitem estimativas de safra ou que demonstrem o quadro momentâneo de uma região, com relação ao desenvolvimento das plantas e às possibilidades de boa produtividade ou não.

Na literatura, diferentes trabalhos tratam da relação entre DPV e produtividade de culturas, bem como da evapotranspiração e condições climáticas ideais para o desenvolvimento das plantas. Gonçalves et al. (2024) discutem de forma peculiar as condições climáticas, incluindo a umidade do ar e o déficit de pressão de vapor e como elas influenciam a produtividade da soja apontando que, no período entre o florescimento e o desenvolvimento de grãos, o DPV entre 0,4 kPa e 1,0 kPa (KiloPascal) é favorável a bons rendimentos.

Partindo-se dos dados de produtividade, DPV e das coordenadas geográficas dos municípios, buscou-se um modelo matemático de estimativa de produtividade, que possa representar aproximadamente 17,9 milhões de hectares, resultante do somatório da área cultivada nos três estados do Sul e a de Mato Grosso do Sul, na safra 2024/2025, frequentemente prejudicados por adversidades climáticas. Para que se tenha uma ideia da diversidade

de ambientes de produção que representam essa grande região, pode-se sintetizar, de modo geral:

1. A Região Sul do Brasil possui clima predominantemente subtropical, o que a diferencia do restante do país, que é majoritariamente tropical. As estações são caracterizadas pela predominância de verões quentes e invernos frios. A distribuição de chuvas ocorre ao longo do ano, sem uma estação seca definida. As geadas são comuns no inverno, principalmente no interior e em altitudes acima de 800 m.
2. Da sub-região Norte do Paraná e do Sul do Mato Grosso do Sul para o Norte, ocorre uma transição climática do clima subtropical para o clima tropical, o que caracteriza o clima do Mato Grosso do Sul como sendo de clima tropical da região central para o Norte.
3. Com relação ao relevo pode-se dizer que na Região Sul ele é marcado por uma grande variação altimétrica, com presença de planaltos, depressões e planícies costeiras. Destacam-se os planaltos do interior, que abrangem grande parte do interior do Paraná, Santa Catarina e o norte do Rio Grande do Sul, possuindo altitudes médias na faixa de 600 a 1.200 m. Existe também terras mais baixas, como a depressão da região central do Rio Grande do Sul e a Campanha Gaúcha, que apresentam altitudes variando de 100 a 500 m. O relevo das regiões norte, noroeste e oeste do Paraná apresenta características distintas, mas que, em conjunto, refletem a transição entre os planaltos paranaenses e os terrenos mais baixos em direção ao vale do rio Paraná. As altitudes médias variam de 400 m a 700 m, porém nas proximidades da depressão do rio Paraná a altitude pode ser inferior a 200 m.
4. Já o Mato Grosso do Sul apresenta um relevo caracterizado por formas variadas, com predominância de planaltos e planícies, compondo paisagens suaves a onduladas. O estado do Mato Grosso do Sul está inserido majoritariamente no Planalto Central Brasileiro, destacando-se quatro regiões geomorfológicas distintas. A primeira é o Planalto do Paraná, localizado mais ao Sul e Sudeste do estado, próximo ao rio Paraná, com altitudes médias entre 500 e 800 metros. A segunda é a Depressão do Rio Paraguai, situada entre os planaltos centrais e a planície pantaneira, com altitudes variando entre 200 e 500 metros. Essa região atua como uma transição entre as áreas mais elevadas e as mais baixas do estado. A terceira é a Planície do Pantanal, localizada na porção Oeste, junto às fronteiras com a Bolívia

e o Paraguai. Trata-se de uma vasta planície de sedimentação recente, sujeita a inundações periódicas, com altitudes geralmente abaixo de 200 metros. Por fim, há ainda uma região de planalto no Centro-Norte e Leste do estado, com altitudes entre 500 e 800 metros, podendo atingir até 900 metros no topo das colinas e chapadões. Essa área também integra o Planalto Central e é caracterizada por terrenos ondulados e boa aptidão agrícola.

5. Considerando toda essa vasta região, a cultura da soja está estabelecida principalmente nos planaltos, preferencialmente em relevos planos a levemente ondulados, com solos profundos e bem drenados (Santos et al., 2006). O uso de correção dos solos e adubação tornou possível o cultivo mesmo em solos de baixa fertilidade natural. São destaques as regiões Norte e Noroeste do Rio Grande do Sul; Sul, Norte e Oeste do Paraná e Norte e Oeste de Santa Catarina.
6. Os solos predominantes são classificados como Latossolos Vermelhos e Nitossolos, derivados de rochas basálticas, de textura argilosa, de alta fertilidade natural, com uso consolidado de plantio direto e rotação de culturas. Nos planaltos do Mato Grosso do Sul o cultivo de soja também é expressivo no sul do estado e na região centro-norte, principalmente em solos classificados como Latossolos Vermelhos e Argissolos Vermelho-Amarelos, de fertilidade média a boa, mas com boa resposta a correções. Ainda considerando toda a região estudada, há cultivo expressivo de soja nas depressões (regiões com altitudes inferiores a 400 m) como a depressão Central do Rio Grande do Sul, principalmente nos solos classificados como Latossolos e Argissolos, de fertilidade natural de média a boa, necessitando correções; e a depressão do Paraguai, no Mato Grosso do Sul, em solos classificados como Latossolos, de textura argilosa, de fertilidade natural de média a baixa, mas com boa corrigibilidade. Há ainda, soja em cultivos ainda não expressivos, porém em expansão, na região da Campanha Gaúcha, em solos classificados como Neossolos e Cambissolos, entre outros, geralmente rasos e de fertilidade natural baixa, porém corrigíveis. Em algumas regiões da depressão do rio Paraná a soja também está presente, porém de modo inexpressivo, cultivada em solos arenosos, classificados como Neossolos Quartzarênicos, de fertilidade natural de média a baixa. Destacam-se também as áreas ou regiões onde a soja não é cultivada na vasta

região estudada, como por exemplo, nas áreas de relevo acidentado, nas áreas de preservação ambiental, em algumas áreas de solos ácidos e mal drenados no sudeste do Rio Grande do Sul, nas regiões serranas do Paraná, Santa Catarina e Rio Grande do Sul e na planície do Pantanal, no Mato Grosso do Sul.

Este detalhamento demonstra a grande heterogeneidade dos ambientes de produção da região compreendida entre o sul do Brasil e o Mato Grosso do Sul. O modelo matemático pretendido, de estimativa de produtividade, é obtido apenas com as coordenadas geográficas de locais, a produtividade média observada de uma safra naquele local e o DPV calculado para o mesmo local na respectiva safra. Outras variáveis que poderiam ser utilizadas como, informações de estrutura e fertilidade dos solos, uso de adubação, cultivares utilizadas, controle de pragas e doenças, entre outras, são muitas vezes inexistentes ou indisponíveis, dada a vastidão da região, tanto em volume quanto no nível necessário de atualização para a construção de modelos mais elaborados. A ideia principal foi ajustar um modelo que estime o mais fielmente possível a realidade/condição hídrica da cultura no campo, mesmo que com um mínimo de informações disponíveis.

O objetivo deste trabalho foi estudar e ajustar um modelo agrometeorológico, para estimativa de produtividade de soja (kg/ha), baseando-se em dados médios de produtividade municipal observados e os seus valores obtidos de DPV, de 306 safras, entre 2019/2020 e 2024/2025, de municípios localizados nos estados do Rio Grande do Sul, Santa Catarina e Paraná, localizados no Sul do Brasil e Mato Grosso do Sul no Centro-Oeste.

Material e Métodos

Foram reunidos dados de produtividade média municipal de soja de 306 safras, dos três estados do Sul e do Mato Grosso do Sul, localizado na região Centro-Oeste (Figura 2). Os dados de produtividade da soja estão publicados nos respectivos boletins de acompanhamento de safras dos órgãos estaduais de economia agrícola e extensão rural de cada estado: Paraná - Seab-Deral (Paraná, 2022, 2023, 2024, 2025), Santa Catarina - Epagri-Cepa (Elias, 2021, 2022, 2023, 2024, 2025), Rio Grande do Sul - Emater-RS (Emater-RS, 2021, 2022, 2023, 2024), Mato Grosso do Sul - sistema Famasul/Aprosoja (Famasul, 2021a, 2021b, 2022, 2023, 2024), além de dados do Instituto Brasileiro e Geografia e Estatística (IBGE, 2022).




Figura 2. Localização de pontos amostrais de municípios com informações de produtividade média municipal de soja e de déficit de pressão de vapor (DPV), para 306 safras, entre 2019/2020 e 2024/2025, dos estados do Rio Grande do Sul, Santa Catarina, Paraná e Mato Grosso do Sul.

Para o número total de safras estudado, foram obtidos dados de produtividade e dados de temperatura e umidade relativa do ar disponíveis para cada período de desenvolvimento da cultura, nas estações do INMET existentes nos municípios ou regiões estudadas (INMET, 2025). O déficit de pressão de vapor (DPV) foi calculado pela equação de Tetens (1930), para o período com maior probabilidade de ocorrência dos estádios da soja compreendidos entre o início do florescimento e o enchimento de grãos. Foram consideradas as épocas de semeadura usuais para municípios e regiões e o ciclo médio das cultivares predominantes. Em função da disponibilidade dos dados climáticos e de produtividade foi possível calcular o DPV para 306 safras, dentro do período das últimas seis safras (2019/2020 a 2024/2025) de soja, que representam melhor a realidade atual da cultura, considerando tecnologias e novas cultivares. Para a região estudada, de modo geral, foram considerados como os meses de florescimento e desenvolvimento de grãos, os meses

de dezembro e janeiro, embora existam para esse item variações em função de épocas de semeadura e ciclo de cultivares.

O cálculo do DPV foi realizado diariamente, sendo que, em função da disponibilidade de dados, no modelo obtido foram utilizadas médias de 6 decênios coincidentes com o florescimento e formação de grãos da soja. Após os cálculos do DPV foram organizados os dados para a realização dos procedimentos estatísticos, obtendo-se uma análise de regressão (Draper; Smith, 1998), que são muito utilizados em estudos de agrometeorologia. Para esse procedimento utilizou-se o software Statsoft (Statsoft, 2007). Aos dados climatológicos foram aplicados um modelo de regressão linear múltipla entre as variáveis produtividade municipal das safras estudadas (kg/ha) como variável dependente e as variáveis independentes latitude e longitude (graus), altitude (m) e DPV médio (kPa) calculado para os períodos críticos da soja, para todas as safras estudadas, conforme Gonçalves et al. (2020; 2024).

Com o modelo obtido foram estimadas as produtividades para todas as safras onde existiam dados de produtividade observada. Além disso foram calculadas as correlações existentes entre a produtividade observada e DPV, entre produtividade estimada e DPV, entre produtividade observada e produtividade estimada, além dos seus coeficientes de determinação. Por último, foi calculado o MAE (erro absoluto médio), que indica a precisão do modelo para cada estimativa realizada.

Resultados e Discussão

Foi ajustada uma equação de regressão pelo método de regressão linear múltipla a partir de diferentes combinações com as variáveis estudadas fixando-se a produtividade de grãos como variável dependente. O resumo da equação linear múltipla encontra-se na Tabela 1.

Tabela 1. Resumo da equação linear múltipla tendo a produtividade de grãos como variável dependente (R= 0,79; R²=0,63).

Variáveis	Beta	B	Significância
Intercepto		4847,84	0,000150
Latitude (lat)	-0,362351	-89,41	0,000000
Altitude (alt)	0,017152	0,05	0,706984
Longitude (long)	0,079758	37,67	0,094984
DPV	-0,723188	-1906,07	0,000000

Com os dados da Tabela 1 foi possível organizar a Equação 1, que possibilita a estimativa da produtividade, dentro da região estudada:

$$\hat{Y} = 4847,84 + (-89,41 * lat) + (0,05 * alt) + (37,67 * long) + (-1906,07 * DPV) \quad \text{Equação 1}$$

Os resultados da regressão múltipla, mostraram um coeficiente de correlação (R) de 0,79423522 e um coeficiente de determinação (R²) de 0,63080958, indicando que aproximadamente 63% da variação da variável dependente (produtividade) é explicada pelas variáveis independentes. Os 37% restantes correspondem a fatores não incluídos no modelo, como variáveis omitidas ou erros aleatórios. A regressão múltipla mostrou alta significância para latitude e DPV, que foram mais importantes que a altitude e a longitude. O DPV teve um peso muito significativo, uma vez que integra dois fatores fundamentais para a produtividade que são a temperatura e a umidade relativa do ar e que variam no tempo e no espaço. A equação de regressão linear múltipla indicou que a significância da latitude foi tão alta quanto a do déficit de pressão de vapor (DPV), evidenciando forte associação com a variável resposta. No entanto, ao se considerar os coeficientes padronizados (Beta na Tabela 1), observou-se que o DPV exerce maior influência relativa sobre a variável dependente. O coeficiente padronizado do DPV foi de -0,72, enquanto o da latitude foi de -0,36, indicando que,

apesar de ambos contribuírem significativamente para o modelo, o DPV possui mais que o dobro do impacto da latitude na variação da resposta. O beta padronizado representa o impacto relativo de uma variável independente sobre a variável dependente e, também, que a padronização permite a comparação de variáveis que podem estar em escalas diferentes. Além disso, o sinal negativo indica relação inversa entre a variável independente e a variável dependente. Esses resultados mostraram a importância do DPV como variável explicativa, sugerindo que mudanças no déficit de pressão de vapor têm maior potencial de influenciar a variável dependente produtividade, do que as variações latitudinais, no contexto avaliado.

A significância da altitude foi baixa no modelo. Porém, o DPV depende muito da altitude. Essa baixa significância pode ocorrer devido ao fato de que a altitude influencia indiretamente o DPV, via temperatura e umidade relativa do ar, não como uma causa direta, uma vez que a altitude não age diretamente sobre a planta, mas modula o ambiente (temperatura, UR, radiação, entre outras). Esse

comportamento pode ser melhor observado quando se comparam áreas em mesma latitude, mas em diferentes altitudes. Por isso, usar variáveis climáticas diretamente (como foi feito no caso do DPV) é mais eficaz nos modelos preditivos. Então, a altitude é sim importante, mas o DPV está traduzindo melhor esse impacto no modelo estatístico. Com o DPV baixo a planta transpira de forma eficiente, sem perder muita água. Há um ambiente úmido e equilibrado, onde a planta mantém estômatos abertos e a fotossíntese funciona normalmente. Com o DPV alto, o ar fica mais seco e a planta pode fechar estômatos para evitar perda hídrica. Isso prejudica a fotossíntese e, com o tempo, reduz o desenvolvimento e a produtividade das plantas. Isso quer dizer que o DPV é um dos principais limitantes ambientais para a produtividade. Estatisticamente, isto indica que aumentos no DPV estão associados a quedas na produtividade de grãos de forma não casual. Isso reforça os resultados da regressão, onde o DPV aparece como variável altamente significativa e com beta elevado. No entanto, é importante enfatizar que um alto DPV nem sempre acarretará uma grande queda de produtividade, uma vez que pode ocorrer de outros fatores importantes, como por exemplo chuvas constantes/regulares e manutenção da

umidade do solo e da sua fertilidade, sejam muito favoráveis, proporcionando ainda assim uma boa produtividade. Esse comportamento ressalta que, embora o DPV seja um excelente indicador atmosférico, ele não atua isoladamente. A produtividade agrícola resulta de uma interação complexa entre atmosfera, solo e manejo. Assim, a presença de umidade suficiente no solo, pode em muitos casos, compensar os efeitos adversos de um alto DPV. No entanto, o beta elevado, de -0,723, mostra, na maioria das vezes, a forte relação inversa entre DPV e produtividade.

Em seguida, a equação obtida foi avaliada quanto à capacidade de estimar a produtividade para cada local, comparando-se com os dados reais de produtividade observada. A partir do emprego da Equação 1, procedeu-se a estimativa da produtividade de grãos para cada município. Posteriormente, para melhor visualização do efeito do DPV sobre a produtividade de grãos, correlacionou-se as produtividades observada e estimada aos valores de DPV, conforme apresentado nas Figuras 3 e 4, respectivamente. Os valores de produtividade média municipal observados foram correlacionados com a produtividade estimada pela Equação 1 (Figura 5).




Figura 3. Correlação entre produtividade observada (kg/ha) e DPV (kPa) nos períodos críticos da soja, obtida com dados de produtividade média municipal, temperatura média e umidade relativa do ar, em 306 safras ocorridas entre 2019/2020 e 2024/2025, nos estados do Rio Grande do Sul, Santa Catarina, Paraná e Mato Grosso do Sul.




Figura 4. Correlação entre produtividade estimada (kg/ha) e DPV (kPa) nos períodos críticos da soja, obtida pela aplicação da equação 1, com dados de produtividade média municipal, temperatura média e umidade relativa do ar, em 306 safras ocorridas entre 2019/2020 e 2024/2025, nos estados do Rio Grande do Sul, Santa Catarina, Paraná e Mato Grosso do Sul.




Figura 5. Correlação entre produtividade observada (kg/ha) e produtividade estimada (kg/ha), em 306 safras ocorridas entre 2019 e 2025, nos estados do Rio Grande do Sul, Santa Catarina, Paraná e Mato Grosso do Sul.

Dessas análises, podem ser destacados três resultados importantes. O primeiro, resumido pela Figura 3, mostra a relação entre a produtividade observada e o DPV, ficando clara a importância do DPV, pela tendência de associação entre boas produtividades e baixo DPV (inferiores a 1). A correlação entre produtividade observada e DPV foi de -0,70. O quadrado deste valor origina um coeficiente de determinação de 0,49. O coeficiente de determinação (R^2) indica o quanto da variação da variável dependente é explicada pela variável (ou variáveis) independente (s) em um modelo de regressão. Neste caso, pôde-se constatar que, individualmente o DPV explica 49% da produtividade observada.

O segundo resultado foi a correlação entre produtividade estimada e DPV, ilustrada pela Figura 4. A correlação entre produtividade estimada e DPV foi de -0,86. O quadrado deste valor origina um coeficiente de determinação de 0,74. O que quer dizer que, individualmente o DPV explica 74% da produtividade estimada. Os dados destas duas correlações mostram que o DPV explica melhor a produtividade estimada do que a observada, indicando que o modelo de estimativa de produtividade está fortemente baseado no DPV. Isto pode ser explicado porque a produtividade observada é mais “complexa”. Ela depende da interação de vários fatores além do DPV, como cultivares utilizadas, datas de semeadura, solos e fertilidade dos solos, pragas e doenças, manejo agrônomo, chuvas, radiação, entre outros. A grande diversificação de ambientes de produção pôde ser verificada na anterior descrição da vasta região focada no trabalho. Então, faz sentido que o DPV explique só 49% da variação da produtividade observada, sendo ele uma peça-chave do modelo. A produtividade estimada é mais “simples”, captando menos os efeitos do complexo produtivo. Se o modelo usa o DPV como uma variável central (ou poucas variáveis, todas correlacionadas com ele), a estimativa vai refletir muito mais diretamente o impacto do DPV. Por isso, a correlação é maior com a produtividade estimada. No entanto, a correlação da produtividade observada com o DPV também é forte e significativa, indicando que quanto maior o DPV, menor a produtividade observada, sendo uma relação estatisticamente relevante.

O terceiro resultado importante foi dado pela correlação feita entre produtividade média municipal observada e produtividade estimada pela Equação 1 (Figura 5). Essa correlação foi de 0,79 e positiva, evidenciando que o modelo é equilibrado e funciona bem, especialmente considerando dados de campo, que têm naturalmente muita variabilidade. Em estatística, uma correlação de 0,70 a 0,90 é considerada

forte. Isso indica que há uma relação linear consistente: conforme a produtividade real aumenta a estimada também tende a aumentar — e vice-versa. Além disso, o modelo tem boa capacidade de replicar o padrão espacial e temporal, sendo que a produtividade real varia no tempo e no espaço (por clima, solo, manejo entre outros aspectos). Essa correlação de 0,79 mostra que o modelo consegue acompanhar bem essas variações, mesmo sem conhecer todos os fatores agrônômicos. Temos que considerar também que erros podem estar presentes, mas as previsões são confiáveis. A correlação não é perfeita ($\neq 1$), ou seja, há erros e dispersão — porém, naturais e esperados. Outra forma de entender esta correlação é observar o coeficiente de determinação. O quadrado de 0,79 é 0,62, indicando que aproximadamente 62% da variação da produtividade observada pode ser explicada pela produtividade estimada pelo modelo. Isso é muito expressivo em modelagem agrícola, onde as variáveis não controladas (manejo, pragas, solos, etc.) respondem por uma parte considerável da variância. Mas a estimativa está fortemente alinhada com a produtividade real, o que valida o uso do modelo para aplicações práticas, como previsão de safras e monitoramentos.

Para melhor entendimento das relações entre produtividade observada e produtividade estimada foi calculado o MAE (erro absoluto médio). O erro absoluto foi obtido pelas diferenças entre cada observação e sua respectiva estimativa. Isto é, pelos resíduos, que podem ser positivos ou negativos. Depois, eliminando-se os sinais negativos dos resíduos, obteve-se os valores absolutos. A média geral entre todos os 306 valores absolutos deste trabalho foi de 421. Interpretando, podemos dizer que o MAE representa, de forma mais intuitiva, o quanto o modelo erra em média, sem considerar o sinal do erro (se superestimou ou subestimou). Ele é ideal para comunicar de forma simples e direta a precisão média do modelo. Assim, para uma estimativa de 3.600 kg/ha para um determinado local, pode-se dizer que, “em média” os erros do modelo são de 421 kg/ha, sendo razoável esperar que a produção real esteja por volta de 3600 ± 421 kg/ha. Mas isso não é garantido para todos os locais, porque tal erro poderá ser maior ou menor dependendo de características específicas de cada local. Considerando que a média das produtividades observadas, das 306 safras, foi de 2984 kg/ha e, levando-se em conta o MAE de 421, podemos calcular o erro percentual médio, que seria dado por $(421/2984) \cdot 100$, que daria um valor de 14,1%. Então, o modelo apresenta um erro médio de aproximadamente 14,1% em relação à

produtividade média observada. Isso significa que, em média, as estimativas se desviam 14,1% dos valores reais. A safra 2021/2022 no sul do Brasil e no Mato Grosso do Sul e a safra 2024/2025 no Rio Grande do Sul (Figura 1), contribuíram para que a produtividade geral das safras estudadas fosse de apenas 2984 kg/ha, inferior à média nacional. Considerando também que o modelo é baseado em variáveis climáticas ou ambientais, com alta variabilidade, abrangendo dados de diversas sub-regiões, o uso de diferentes cultivares e diversas condições de manejo, o desempenho do modelo é bom. Além disso, como ele busca uma estimativa geral e não valores exatos ponto a ponto, 14,1% é um erro relativamente baixo para esse tipo de modelagem em agronomia, principalmente porque a área estudada é muito grande, neste caso, quase 18 milhões de hectares.

Conclusão

Os resultados obtidos demonstraram que o déficit de pressão de vapor (DPV) exerce influência direta sobre a produtividade da soja. O modelo de regressão desenvolvido apresentou desempenho consistente, com erro médio absoluto (MAE) de apenas 14%, evidenciando boa capacidade preditiva em condições de campo. Essa equação permite estimar a produtividade em função do DPV, oferecendo aplicabilidade prática em diferentes contextos: monitoramento em tempo real, previsão de safras e perdas relacionadas a perdas de colheitas. Assim, conclui-se que o DPV é um indicador agrometeorológico robusto, capaz de sintetizar a resposta produtiva da soja às condições atmosféricas, reforçando o seu potencial de uso tanto em pesquisa quanto em aplicações operacionais.

Referências

- CONAB. **Acompanhamento da safra brasileira:** grãos, safra 2024/25, 7º levantamento. Brasília, DF, 2025. Disponível em: <https://www.gov.br/conab/pt-br/atualizacao/informacoes-agropecuarias/safras/safra-de-graos/boletim-da-safra-de-graos/7o-levantamento-safra-2024-25/boletim-da-safra-de-graos>. Acesso em: 04 set. 2025.
- DRAPER, N. R.; SMITH, H. **Applied regression analysis**. 3rd ed. New York: John Wiley & Sons, 1998. 716 p.
- ELIAS, H. T. Soja. **Boletim Agropecuário**, n. 110, p. 16-20, 2022. Disponível em: https://docweb.epagri.sc.gov.br/website_cepa/Boletim_agropecuário/boletim_agropecuário_n110.pdf. Acesso em: 15 fev. 2023.
- ELIAS, H. T. Soja. **Boletim Agropecuário**, n. 121, p. 21-24, 2023. Disponível em: <https://publicacoes.epagri.sc.gov.br/ba/article/view/1700/1557>. Acesso em: 30 jun. 2023.
- ELIAS, H. T. Soja. **Boletim Agropecuário**, n. 133, p. 22-26, 2024. Disponível em: <https://publicacoes.epagri.sc.gov.br/ba/article/view/1879/1679>. Acesso em: 18 nov. 2024.
- ELIAS, H. T. Soja. **Boletim Agropecuário**, n. 140, p. 22-26, 2025. Disponível em: <https://publicacoes.epagri.sc.gov.br/ba/article/view/1971/1780>. Acesso em: 31 jan. 2025.
- ELIAS, H. T. Soja. **Boletim Agropecuário**, n. 96, p. 19-22, 2021. Disponível em: https://docweb.epagri.sc.gov.br/website_cepa/Boletim_agropecuário/boletim_agropecuário_n96.pdf. Acesso em: 15 fev. 2023.
- EMATER-RS. **Estimativa da safra de verão 2021-2022**. março, 2022. Disponível em: https://www.emater.tche.br/site/arquivos_pdf/safra/safraTabela_08032022.pdf. Acesso em: 2 set. 2022.
- EMATER-RS. **Estimativa da safra de verão 2022-2023**. março, 2023. Disponível em: https://www.emater.tche.br/site/arquivos_pdf/safra/safraTabela_07032023.pdf. Acesso em: 13 nov. 2024.
- EMATER-RS. **Safra de verão 2020-2021:** estimativas atuais de produtividade, área e produção. março, 2021. Disponível em: https://www.emater.tche.br/site/arquivos_pdf/safra/safraTabela_25032021.pdf. Acesso em: 15 fev. 2023.
- EMATER-RS. **Segunda estimativa da safra de verão 2023/2024**. março, 2024. Disponível em: https://www.emater.tche.br/site/arquivos_pdf/safra/safraTabela_05032024.pdf. Acesso em: 13 nov. de 2024.
- FAMASUL. **Boletim Semanal Casa Rural - Agricultura:** produtividade da soja safra 2020-2021. circular 404, abril 2021a. Disponível em: <https://portal.sistemafamasul.com.br/sites/default/files/boletimcasapdf/404%20-%20BOLETIM%20SEMANAL%20CASA%20RURAL%20-%20AGRICULTURA%20-20CIRCULAR%20404%20-%20PRODUTIVIDADE%20DE%20SOJA%20SAFRA%202020-2021.pdf>. Acesso em: 8 maio 2023.
- FAMASUL. **Boletim Semanal Casa Rural - Agricultura:** circular 431, 03 nov. 2021b. Disponível em: <https://portal.sistemafamasul.com.br/sites/default/files/boletimcasapdf/431%20-20BOLETIM%20SEMANAL%20CASA%20RURAL%20-%20AGRICULTURA%20-20CIRCULAR%20431%2003.11.21.pdf>. Acesso em: 24 out. 2023.
- FAMASUL. **Boletim Semanal Casa Rural - Agricultura:** produtividade da soja safra 2021-2022. circular 454, 26 abr. 2022. Disponível em: <https://portal.sistemafamasul.com.br/sites/default/files/boletimcasapdf/454%20-20BOLETIM%20SEMANAL%20CASA%20RURAL%20-%20AGRICULTURA%20-20CIRCULAR%20454%2004.26.22.pdf>. Acesso em: 15 fev. 2023.

com.br/sites/default/files/boletimcasapdf/454%20-%20BOLETIM%20SEMANAL%20CASA%20RURAL%20-%20AGRICULTURA%20-%20CIRCULAR%20454%2026.04.2022.pdf. Acesso em: 24 out. 2023.

FAMASUL. **Boletim Semanal Casa Rural - Agricultura:** produtividade da soja safra 2022-2023. circular 509, 23 maio 2023. Disponível em: <https://portal.sistemafamasul.com.br/sites/default/files/boletimcasapdf/509%20-%20BOLETIM%20SEMANAL%20CASA%20RURAL%20-%20AGRICULTURA%20-%20CIRCULAR%20509%20-%20PRODUTIVIDADE%20DA%20SOJA%20%20SAFRA%202022-2023%2023.05.2023.pdf>. Acesso em: 24 out. 2023.

FAMASUL. **Boletim Semanal Casa Rural - Agricultura:** produtividade da soja safra 2023-2024. circular 560, 22 maio 2024. Disponível em: https://portal.sistemafamasul.com.br/sites/default/files/boletimcasapdf/560%20-%20BOLETIM%20SEMANAL%20CASA%20RURAL%20-%20AGRICULTURA%20-%20CIRCULAR%20560%20%2022.05.2024%20-%20PRODUTIVIDADE%20DA%20SOJA%20SAFRA%202023-2024_1.pdf. Acesso em: 24 fev. 2025.

GONÇALVES, S. L.; FARIAS, J. R. B.; CRUSIOL, L. G. T.; SIBALDELLI, R. N. R.; NEUMAIER, N. **Déficit de pressão de vapor (DPV) como referência de produtividade em soja - primeira aproximação.** Londrina: Embrapa Soja, 2024. 9 p. (Embrapa Soja. Boletim de pesquisa e desenvolvimento, 31).

GONÇALVES, S. L.; OLIVEIRA, M. C. N. de; FARIAS, J. R. B.; SIBALDELLI, R. N. R. Mathematical equations representing the impacts of climatic factors on soybean productivity in the 2018/2019 crop season in the Parana State, Brazil. **Agrometeoros**, v. 28, e026748, 2020.

IBGE. **Pesquisa Agrícola Municipal:** Tabela 5457 - Área plantada ou destinada à colheita, área colhida, quantidade produzida, rendimento médio e valor da produção das lavouras temporárias e permanentes. Rio de Janeiro, 2022. Disponível em: <https://sidra.ibge.gov.br/tabela/5457>. Acesso em: 25 fev. 2022.

INMET. **Estações meteorológicas.** Brasília, DF, 2025. Disponível em: <https://mapas.inmet.gov.br/>. Acesso em: 22 mar. 2025.

PARANÁ. Secretaria de Agricultura e Abastecimento. Departamento de Economia Rural (DERAL). **Estimativas de safra:** área, produção e evolução de safra: quadros 2022. Curitiba: 2022. Disponível em: <https://www.agricultura.pr.gov.br/deral/safras>. Acesso em: 22 mar. 2022.

PARANÁ. Secretaria de Agricultura e Abastecimento. Departamento de Economia Rural (DERAL). **Estimativas de safra:** área, produção e evolução de safra: quadros 2023. Curitiba, 2023. Disponível em: <https://www.agricultura.pr.gov.br/deral/safras>. Acesso em 14 fev. 2023.

PARANÁ. Secretaria de Agricultura e Abastecimento. Departamento de Economia Rural (DERAL). **Estimativas de safra:** área, produção e evolução de safra: quadros 2024. Curitiba, 2024. Disponível em: <https://www.agricultura.pr.gov.br/deral/safras>. Acesso em 10 mar. 2024.

PARANÁ. Secretaria de Agricultura e Abastecimento. Departamento de Economia Rural (DERAL). **Estimativas de safra:** área, produção e evolução de safra: safra 24/25. Curitiba, 2025. Disponível em: <https://www.agricultura.pr.gov.br/deral/safras>. Acesso em 24 fev. 2025.

SANTOS, H. G. dos; JACOMINE, P. K. T.; ANJOS, L. H. C. dos; OLIVEIRA, V. A. de; OLIVEIRA, J. B. de; COELHO, M. R.; LUMBRERAS, J. F.; CUNHA, T. J. F. (ed.). **Sistema brasileiro de classificação de solos.** 2. ed. Rio de Janeiro: Embrapa Solos, 2006. 306 p.

SENTELHAS, P. C.; BATTISTI, R.; CÂMARA, G. M. S.; FARIAS, J. R. B.; HAMPF, A. C.; NENDEL, C. The soybean yield gap in Brazil - magnitude, causes and possible solutions for sustainable production. **Journal of Agricultural Science**, v. 153, n. 8. p. 1394-1411, 2015.

STATSOFT. **Statistica for Windows:** computer program manual. version 7. Tulsa, 2007.

TETENS, O. Über einige meteorologische Begriffe. **Zeitschrift für Geophysik**, v. 6, n. 1, p. 297-309, 1930.